

III 回帰分析とその統計的性質

母集団: $Y_i = \alpha + \beta X_i + \varepsilon_i$ — 無作為抽出 → 標本($n=100$): $Y_i = a + bX_i + e_i$ (e_i (最小 2 乗残差)
 Y_i :成績, X_i :勉強時間, ε_i :誤差 何通りの標本抽出が可能、(a,b)は確率分布する

$$b = \frac{\sum w_i Y_i}{\sum w_i X_i} = \beta + \frac{\sum w_i \varepsilon_i}{\sum w_i X_i}, \quad w_i = \frac{X_i - \bar{X}}{\sum (X_i - \bar{X})^2} \quad \left(\sum w_i = 0, \sum w_i (X_i - \bar{X}) = \sum w_i X_i = 1 \right)$$

$$a = (\alpha + \beta \bar{X} + \bar{\varepsilon}) - b \bar{X} = \alpha - (b - \beta) \bar{X} + \bar{\varepsilon} = \alpha + \sum \left(\frac{1}{n} - w_i \bar{X} \right) \varepsilon_i$$

0. 期待値、分散演算子の計算公式

(1)期待値 $E(X) = \sum X_i f(X_i)$ or $E(X) = \int X f(X) dX$

$$E(bx) = bE(x), E(a+x) = a + E(x), E(a+bx) = a + bE(x)$$

(2)分散 $V(X) = E\{(X - E(X))^2\} = \sum (X_i - E(X_i))^2 f(X_i)$ or $E(X) = \int (X - E(X))^2 f(X) dX$

$$V(bx) = b^2 V(x), V(a+x) = V(x), V(a+bx) = b^2 V(x)$$

(3)共分散 $Cov(X, Y) = E\{(X - E(X))(Y - E(Y))\}$

$$Cov(X, X) = V(X), Cov(X, Y) = Cov(Y, X), Cov(a+X, Y) = Cov(X, Y), Cov(bX, Y) = bCov(X, Y)$$

1. 誤差項 ε 、説明変数 X の標準的仮定 (p-25-27)

(U1) ε_i の期待値はゼロ: $E(\varepsilon_i) = 0$

(U2) ε_i の分散均一性: $Var(\varepsilon_i) = E\{(\varepsilon_i - E(\varepsilon_i))^2\} = E(\varepsilon_i^2) = \sigma^2$, σ :標準誤差(standard error)

(U3) ε_i は互いに無相関: $Cov(\varepsilon_i, \varepsilon_j) = E\{(\varepsilon_i - E(\varepsilon_i))(\varepsilon_j - E(\varepsilon_j))\} = E(\varepsilon_i \varepsilon_j) = 0$

(U4) ε_i 正規分布に従う(中心極限定理): U1-4 をまとめると $\varepsilon_i \sim NID(0, \sigma^2)$

(X1) X_i と ε の無相関 (X の外生性): $Cov(X_i, \varepsilon_i) = 0$, $E(X_i \varepsilon_i) = X_i E(\varepsilon_i) = 0$

2. 最小 2 乗推定量 a, b の性質

最小 2 乗推定量は **BLUE(Best Linear Unbiased Estimator, 最良線形不偏推定量)** である

2.1 不偏性(unbiasedness) p-28, 275

$$E(b) = \beta + \sum w_i E(\varepsilon_i) = \beta, E(a) = \alpha \leftarrow (U1), (X1)$$

2.2 有効性¹(最小分散性、効率性:efficiency) p-31, 275

$$\sigma_b^2 = E(b - E(b))^2 = \sum w_i^2 E(\varepsilon_i^2) = \sigma^2 \sum w_i^2 = \sigma^2 / \left(\sum (X_i - \bar{X})^2 \right) \leftarrow (U1), (U2), (U3), (X1)$$

$$\sigma_a^2 = E(a - E(a))^2 = E\left[(b - \beta)^2 \bar{X}^2 - (b - \beta) \bar{X} \bar{\varepsilon} + \bar{\varepsilon}^2\right] = \sigma^2 \left[\frac{\bar{X}^2}{\sum (X_i - \bar{X})^2} + \frac{1}{n} \right] = \frac{\sigma^2 \sum X_i^2}{n \sum (X_i - \bar{X})^2}$$

・任意の線形推定量 $C = c_0 + \sum c_i Y_i$ が不偏性 $E(C) = c_0 + \sum c_i (\alpha + \beta X_i) = \beta$ を満たすには、 $c_0 = 0$, $\sum c_i = 0$, $\sum c_i X_i = 1$ である必要がある → 任意の線形不偏推定量は

$$C = \sum c_i Y_i, \sum c_i = 0, \sum c_i X_i = \sum c_i X_i = 1$$

・ C の分散 $var(C) = \sigma^2 \sum c_i^2$ を最小にする c_i は $L = \sum c_i^2 - \lambda_1 \sum c_i - \lambda_2 (\sum c_i X_i - 1)$ より $\partial L / \partial c_i = 2c_i - \lambda_1 - \lambda_2 X_i = 0$, $\sum c_i = 0$, $\sum c_i X_i = 1$ より求まる。最初の条件 $c_i = (\lambda_1 + \lambda_2 X_i) / 2$ を第 2、3 条件に代入すると $n \lambda_1 + \lambda_2 \sum X_i = 0 \rightarrow \lambda_1 = 0$, $\lambda_1 \sum X_i + \lambda_2 \sum X_i^2 = 2 \rightarrow \lambda_2 = 2 / (\sum X_i^2)$ となり、このとき $c_i = X_i / \sum X_i^2 = w_i$

2.3 Gauss-Markov Theorem p-31

古典的回帰モデル((U-1),(U-2),(U-3),(X-1)が成り立つ)では最小 2 乗推定量は BLUE となる

2.4 $\varepsilon \sim NID(0, \sigma^2)$ のときの最小 2 乗推定量 a, b の分布 p-30

$$a \cdots N(\alpha, \sigma_a^2), b \cdots N(\beta, \sigma_b^2) \text{ だから、 } Z = (b - \beta) / \sigma_b \cdots N(0, 1) \quad \sigma_b = \sigma / \sqrt{\sum (X_i - \bar{X})^2}$$

このとき σ^2 の不偏推定量 $s^2 = \sum \varepsilon_i^2 / (n - k)$ で代用した $s_b = s / \sqrt{\sum (X_i - \bar{X})^2}$ で標準化すると

¹ 不偏推定量の中で最も分散が小さい推定量を有効推定量(efficient estimator)という

$t = (b - \beta) / s_b$ は自由度 $n-k$ の t 分布に従う (k はパラメタの数)。

3. 仮説検定 p-33

3.1 両側検定：リカードの等価定理の検証

①仮説の設定： $C_t = \beta_0 + \beta_1 Y_t + \beta_2 B_t + \varepsilon_t$ において $H_0: \beta_2 = 0$ $H_1: \beta_2 \neq 0$

②帰無仮説の受容域： H_0 が正しいとしたら $b_2 \sim N(0, \sigma_b)$ だが $t = (b_2 - 0) / s_b = b_2 / s_b \sim t(n-3)$ となる

るので $1-\alpha$ の確率で統計量 t は $\Pr(-t_{\alpha/2} < t = \frac{b - \beta_0}{s_b} < t_{\alpha/2}) = 1-\alpha$ の範囲内に入る。

③仮説検定の実施：計算された t がこの受容域に入っている (いない) とき、帰無仮説は有意水準 α で採択 (棄却) される、という。

※帰無仮説 $H_0: \beta = 0$ の検定統計量 $t = b / s_b$ を「 t 値 (t -ratio)」とよぶ。 t 値が絶対値で 2 よりも大きいとき当該変数は統計的に有意だと考える (2 t ルール)。

3.2 片側検定：パンは必需財か否かの検定

①仮説の設定： $\ln Q_t = \beta_0 + \beta_1 \ln P_t + \beta_2 \ln M_t + \beta_3 Z_t + \varepsilon_t$ において $H_0: \beta_2 = 1$ $H_1: \beta_2 < 1$

②帰無仮説の受容域： H_0 が正しいとしたら $b_2 \sim N(0, \sigma_b)$ だが $t = (b_2 - 1) / s_b \sim t(n-4)$ となるの

で $1-\alpha$ の確率で統計量 t は $\Pr(-t_{\alpha} < t = \frac{b - 1}{s_b}) = 1-\alpha$ の範囲内に入る。

③仮説検定の実施：計算された t がこの採択域に入っている (いない) とき、帰無仮説は有意水準 α で採択 (棄却) される。

$t = (0.612 - 1) / 0.149 = -2.607 > t_{5\%}(23-4) = -1.729$ より帰無仮説が棄却されるので、「パンは必需財である」といえる。

Excel の分析ツール(回帰分析)の結果 (1980-2002 年)

回帰統計		係数	標準誤差	t	P-値	下限	95%上限	95%
重相関 R	0.926切片	3.970	1.552	2.558	0.019	0.722	7.218	
重決定 R2	0.858X 値 1	-1.009	0.135	-7.472	0.000	-1.292	-0.727	
補正 R2	0.836X 値 2	0.612	0.149	4.120	0.001	0.301	0.924	
標準誤差	0.016X 値 3	-0.461	0.310	-1.487	0.153	-1.109	0.188	
観測数	23							

重決定 R²：決定係数 R², 補正 R²：自由度修正済み決定係数 \bar{R}^2 、重相関 R： $\sqrt{R^2}$

標準誤差： $s = \sqrt{\sum e_i^2 / (n-k)}$, p 値： $H_0: \beta = 0$ のもとで t が生じる確率 $1 - \Pr(-t < b/s_b < t)$

β の区間推定： $\Pr(b - t_{5\%/2} \cdot s_b < \beta < b + t_{5\%/2} \cdot s_b) = 0.95$

4. 予測 p-38

4.1 条件付予測

点予測値 $\hat{Y}_t = a + bX_t$, 予測誤差 $e_t = Y_t - \hat{Y}_t = (\alpha - a) + (\beta - b)X_t + \varepsilon_t$

4.2 最良線形不偏予測量(Best Linear Unbiased Predictor)

$E(e_t) = 0$, $E(\hat{Y}_t) = E(a) + E(b)X_t = \alpha + \beta X_t = E(Y_t)$ 不偏予測量

$\text{Var}(e_t) = E\{(\alpha - a) + (\beta - b)X_t\}^2 + E(\varepsilon_t^2) = E(a - \alpha)^2 + X_t^2 E(b - \beta)^2 + 2X_t E\{(\alpha - a)(\beta - \beta)\} + E(\varepsilon_t^2)$
 $= \sigma^2 [1/n + (X_t - \bar{X})^2 / \{\sum (X_i - \bar{X})^2\}] = \sigma^2 / n + \sigma^2_b (X_t - \bar{X})^2$

$\text{Var}(\hat{Y}_t) = \sigma^2 [1 + 1/n + (X_t - \bar{X})^2 / \{\sum (X_i - \bar{X})^2\}] = \sigma^2 (1 + 1/n) + \sigma^2_b (X_t - \bar{X})^2$

補足 1 エクセルで回帰分析を行うには

1 ツール→分析ツール→回帰分析を選択します。

分析ツールが表示されない場合はツール→アドインで分析ツールをチェックしましょう

2 回帰分析ツールに入ると、下のような窓が表示される。


入力元

- ①入力 Y 範囲を指定：マウスで範囲指定します
- ②入力 X 範囲を指定：マウスで範囲指定します。複数の説明変数なら B29:D35 のように
- ③変数名を入力範囲に加えてラベルにチェックをいれます。

出力オプション

- ①出力先：「新規又は次のワークシート」にしましょう。
- ②残差(R)、残差グラフ、観測値グラフにチェックを入れます。

3 推定結果の読み取り



概要		分散分析表					
回帰統計			自由度	変動	分散	分散比	有意 F
重相関 R	0.867103	回帰	1	1.7E+09	1.7E+09	63.6321	8.62E-08
重決定 R ²	0.751867	残差	21	5.61E+08	26701760		
補正 R ²	0.740051	合計	22	2.26E+09			
標準誤差	5167.375						
観測数	23						

	係数	標準誤差	t	P-値	下限 95%	上限 95%
切片	12773.03	6893.564	1.852892	0.078004	-1562.92	27108.98
専有面積	2807.363	351.9333	7.976973	8.62E-08	2075.477	3539.248

(1)回帰統計 (モデルの説明力をチェック)

重決定 R² : 決定係数 R², 補正 R² : 自由度修正済み決定係数 \bar{R}^2 ($R^2 > \bar{R}^2$)

重相関 R : $\sqrt{R^2}$

標準誤差 : $s = \sqrt{\sum e_i^2 / (n - k)}$ 残差 ε_i の母標準偏差 σ の不偏推定量

(2)分散分析表 (データ変動の要因分解) テキスト p-79

TSS(合計変動, $\sum (Y_i - \bar{Y})^2$) = ESS(回帰変動, $\sum (\hat{Y}_i - \bar{Y})^2$) + RSS(残差変動, $\sum e_i^2$)

分散比 = {ESS/(k-1)} / {RSS/(n-k)} → H₀: $\beta_1 = \beta_2 = 0$ の検定

有意 F : 分散比が 0 となる確率

(3)回帰係数表 (説明変数の影響力のチェック)

係数 : β の最小 2 乗推定量 b

回帰係数の標準誤差 : $s_b = \sqrt{s^2 / \sum (X_i - \bar{X})^2}$

t 値 : $t = \frac{b}{s_b}$ 絶対値が 2 より大きいと有意 (正確には t 分布表あるいは p 値を見る)

p 値 : H₀: $\beta = 0$ のもとで t が生じる確率 $1 - \Pr(-t < b/s_b < t)$

下限/上限 95% : β の区間推定、 $\Pr(b - t_{2.5\%}/s_b < \beta < b + t_{2.5\%} \cdot s_b) = 0.95$